

DOI: 10.19650/j.cnki.cjsi.J2311190

# 基于多任务学习的快速序列视觉呈现脑电图分类\*

谢平<sup>1,2</sup>, 胡锦涛<sup>1</sup>, 江国乾<sup>1,3</sup>, 王鹏宇<sup>1</sup>, 门延帝<sup>1</sup>

(1. 燕山大学电气工程学院 秦皇岛 066004; 2. 河北省智能康复及神经调控重点实验室 秦皇岛 066004;  
3. 河北省测试计量技术及仪器重点实验室 秦皇岛 066004)

**摘要:**针对快速序列视觉呈现的脑电图数据存在样本不平衡问题,提出一种基于多任务学习的快速序列视觉呈现脑电图分类模型。首先,建立深度共享特征提取模块,利用卷积神经网络自动学习共享参数,提取与任务关联的深度特征;其次,基于分类任务和超球约束任务构造多任务目标函数,利用两种任务的联合学习提取更有效的判别特征,提高模型泛化性。在快速序列视觉呈现公开数据集中进行实验,与常见的脑电分类模型 DeepConvNet、EEGInception、DRL 以及 EEGNet 相比,提出的 Multi-task EEGNet 在 32 个受试者中平均 AUC 分别提升 3.57%、1.84%、6.22% 和 2.09%。实验结果表明,提出的多任务学习模型能更充分地提取判别特征,有效提升模型分类性能,较好地解决 EEG 分类任务中样本不平衡问题。

**关键词:**脑电图;快速序列视觉呈现;多任务学习;卷积神经网络

中图分类号: TH79 文献标识码: A 国家标准学科分类代码: 510.40

## Classification of rapid serial visual presentation based EEG with multi-task learning

Xie Ping<sup>1,2</sup>, Hu Jincheng<sup>1</sup>, Jiang Guoqian<sup>1,3</sup>, Wang Pengyu<sup>1</sup>, Men Yandi<sup>1</sup>

(1. Institute of Electric Engineering, Yanshan University, Qinhuangdao 066004, China; 2. Key Laboratory of Intelligent Rehabilitation and Neuromodulation of Hebei Province, Qinhuangdao 066004, China; 3. Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Qinhuangdao 066004, China)

**Abstract:** To address the issue of sample imbalance in EEG obtained through rapid serial visual presentation (RSVP), a multi-task learning model for EEG classification is proposed. Firstly, a deep shared feature extraction module is established, which utilizes a convolutional neural network to automatically learn shared parameters and extract depth-related features associated with tasks. Then, a multi-task objective function is constructed based on the classification task and hyper-sphere constraint task, utilizing the joint learning of these two tasks to extract more effective discriminative features and improving the model's generalization performance. Experiments are implemented on a public RSVP EEG dataset. Compared with commonly used EEG classification models such as DeepConvNet, EEGInception, DRL, and EEGNet, the proposed model named Multi-task EEGNet can achieve the average AUC improvement of 3.57%, 1.84%, 6.22%, and 2.09% respectively, across 32 subjects. The results indicate that the proposed multi-task learning model can extract discriminative features more fully, effectively improve model classification performance, and better solve the sample imbalance problem in EEG classification tasks.

**Keywords:** electroencephalography (EEG); rapid serial visual presentation; multi-task learning; convolutional neural network

## 0 引言

脑机接口 (brain-computer interface, BCI) 是一种硬件和软件通信系统,它通过使用脑电图 (electroence-

phalographic, EEG) 活动产生的控制信号,使人在没有外周神经和肌肉参与情况下,与外界环境进行交互<sup>[1]</sup>。最初,BCI 系统主要用于改善患有运动障碍 (如肌萎缩侧索硬化症) 和语言功能障碍患者的生活质量<sup>[2-3]</sup>,并开发出运动想象<sup>[4]</sup>、抑郁症诊断<sup>[5]</sup>及癫痫检测<sup>[6]</sup>等范式与研究

收稿日期:2023-03-18 Received Date: 2023-03-18

\* 基金项目:国家自然科学基金(U20A20192,62076216)、河北省自然科学基金(F2022203079)项目资助

方法。随着信号采集方式以及信号解码算法等技术的进步,BCI系统也被应用于健康人群。快速序列视觉呈现(rapid serial visual presentation, RSVP)作为BCI 3种经典范式之一,能够提高普通人的目标检测能力,在军事侦察、医疗保健等领域得到了学者广泛关注,成为研究热点<sup>[7]</sup>。

RSVP是指在固定空间位置快速播放目标与非目标两类刺激图像<sup>[8]</sup>,受试者看到目标图像时,大脑会根据这一视觉刺激诱发事件相关电位(event related potential, ERP),包括P100、N200、P300等ERP成分<sup>[9-11]</sup>。可通过检测EEG信号中是否存在P300等ERP成分,判断当前EEG信号对应的刺激图像是否是目标图像,从而实现目标检测。

基于RSVP的BCI系统目标检测效果取决于对单次ERP成分的分类精度。近年来,随着深度学习的发展,ERP分类算法精度越来越高,但是RSVP的样本不平衡问题始终制约其进一步提升。一些研究表明,数量较多的类别数据会主导分类决策,提高虚警率<sup>[6,12]</sup>,因此样本不平衡问题会严重影响RSVP脑电图分类性能。

为缓解EEG领域的样本不平衡问题,学者主要从2个角度开展研究,类别再平衡策略和权值再平衡策略。类别再平衡策略通过改变EEG原始数据中各个类别的分布来缓解样本不平衡问题。Li等<sup>[13]</sup>提出解耦表征学习DRL模型,从原始数据中随机抽取数据组成目标-目标、非目标-非目标以及目标-非目标3种数量比例为1:1:2的样本对,通过对比学习训练特征提取网络,再对非目标脑电数据进行下采样,用平衡后的脑电数据训练分类器,缓解了样本不平衡问题,但模型训练时间较长,不利于进行在线实验。Xu等<sup>[14]</sup>提出BWGAN-GP模型来生成RSVP目标脑电数据,使两类脑电数据数量达到平衡,在EEGNet模型上相比使用原始不平衡脑电数据,AUC提升3.7%。然而,采用人工生成数据的方式不仅会增加校准时间,还容易受到不良数据的干扰。而权值再平衡策略主要是调整损失函数中各个类别的权值,类别数量越多权值越小,这样可以明显提高模型对样本不平衡数据集的分类性能<sup>[15]</sup>。因此,目前大多数深度学习EEG分类算法都是通过使用带权重的交叉熵(weighted cross-entropy, WCE)损失函数,来缓解样本不平衡问题。基于此,DeepConvNet<sup>[16]</sup>、EEGNet<sup>[17]</sup>和EEG-Inception<sup>[18]</sup>等EEG分类模型在ERP分类任务上取得了较好的分类效果。

此外,异常检测领域主要研究样本不平衡问题,不少研究者针对不同类型的数据提出了相应的解决办法<sup>[19]</sup>。Tax等<sup>[20]</sup>提出支持向量数据描述(support vector data description, SVDD)算法,用超球体代替SVM的超平面,将正常数据映射到超球体内部,异常数据映射到超球体

外部,从而对正常数据与异常数据进行分类。Ruff等<sup>[21]</sup>对SVDD进行改进,提出Deep SVDD算法,用神经网络代替核方法映射,提高了模型泛化能力,取得不错的分类效果。因此,将异常检测领域解决样本不平衡问题的方法和思想引入EEG领域是一个可行的尝试。

另外,在ERP分类算法研究中,大部分算法都是采用单任务学习(single-task learning, STL)进行预测建模,可能会忽略其他有助于分类的潜在信息,并且容易受到数据噪声的影响。相比之下,多任务学习(multi-task learning, MTL)不仅利用多个学习任务提供互补信息,还对不同任务噪声模型进行平均,能有效提升模型的泛化性能<sup>[22-23]</sup>。

因此,本文提出基于多任务学习的快速序列视觉呈现脑电图分类模型。本文的贡献在于:

1)将异常检测领域的单分类方法SVDD引入EEG领域,通过在特征空间构造超球体对目标与非目标脑电数据进行约束,缓解样本不平衡问题;

2)采用多任务学习策略,利用分类任务和超球约束任务联合学习优化特征,提高模型泛化性能。

## 1 基于多任务学习的RSVP分类模型

基于多任务学习的RSVP脑电图分类模型框架主要由深度共享特征提取模块和多任务目标函数构造模块2部分组成,如图1所示。在进行预处理和数据转换后,脑电数据被输入到深度共享特征提取模块中,通过卷积神经网络自动学习和提取共享特征。然后,通过分类任务与超球约束任务构造多任务目标函数,对提取的特征进行优化和筛选,最后使用分类任务的输出结果对脑电数据进行分类。

### 1.1 深度共享特征学习模块

本文所采用的深度共享特征提取网络如图1所示,该网络由EEGNet模型<sup>[17]</sup>分类层之前的网络结构加上一层全连接层组成。深度共享特征提取网络由3部分组成。第1部分包括8个卷积核大小为(1,64)的二维卷积层和卷积核大小为(C,1)的深度卷积层(C为脑电通道数量),前者用于提取不同频带EEG信号的频率信息,后者用于提取特定频率对应的空间信息。深度卷积层后面跟随的平均池化层大小为(1,4),用于将采样率降低为原来的1/4。第2部分主要使用可分离卷积,包括卷积核大小为(1,16)的深度卷积和维度为16的点卷积,不仅可以减少训练参数,还可以对提取的时空特征进行解耦融合,以整合时空信息。后面的平均池化层大小为(1,8),主要用于特征降维。第3部分则是一个全连接层,对特征进一步降维的同时减少超球体球心参数,缩短训练时间。

### 1.2 多任务目标函数构造

基于多任务学习的 RSVP 脑电图分类模型进行分类任务和超球约束任务的联合学习,其结构如图 1 所示。超球约束任务在异常检测领域被广泛使用,用于区分正常数据和异常数据。因此,分类任务和超球约束任务之间存在相关性,这种联合学习有助于从数据中挖掘出更多有效的特征。

#### 1) 分类任务

分类任务是该模型的一个主要任务,通过全连接层进行 2 分类,以区分目标和非目标脑电数据为目标。该全连接层输出维度为 2,经过 softmax 函数处理后,每个维度的值都在 0~1 且两数之和为 1。当维度 0 的值大于维度 1 的值时,分类输出为 0,表示当前脑电数据为非目标数据;反之,则分类输出为 1,代表当前脑电数据为目标数据。

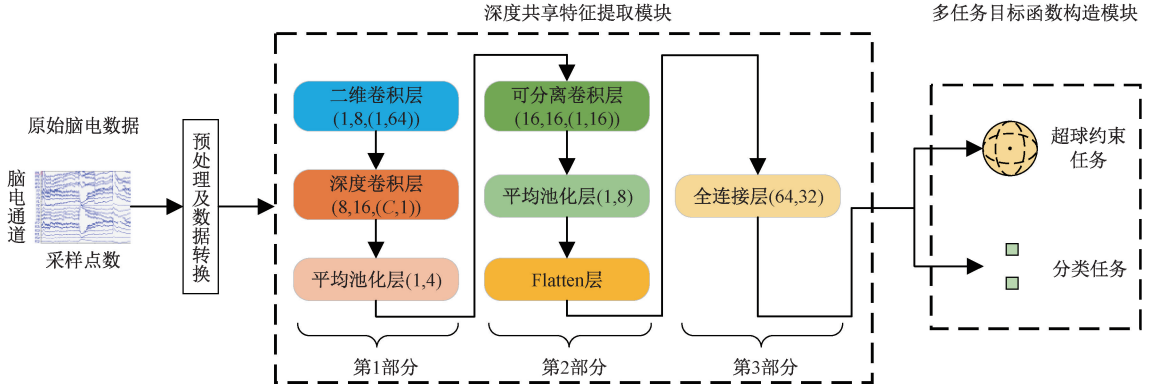


图 1 RSVP 脑电分类模型框架

Fig. 1 EEG classification model framework in RSVP

#### 2) 超球约束任务

在异常检测领域,SVDD 方法通常用于构造一个超球体,将正常数据映射到该超球体内,将异常数据映射到超球体外。同时,通过最小化超球体的尺寸,确定正常点与异常点的边界,将其作为判断异常的阈值。如图 2 所示,将 SVDD 方法应用于 RSVP 脑电数据时,由于非目标脑电数据远多于目标脑电数据,且目标脑电数据存在 ERP 波形成分,因此将从非目标脑电数据提取的特征视为正常特征,用圆形表示;从目标脑电数据提取的特征视为异常特征,用五角星表示。




图 2 超球体示意图

Fig. 2 Hypersphere diagram

针对输入空间  $X \subseteq R^d$  和输出空间  $F \subseteq R^p$ ,  $d$  和  $p$  分别为输入、输出空间维度。定义一个特征提取网络  $\phi(\cdot; w): X \rightarrow F$ , 其中  $w$  代表网络的参数。因此,给定参数  $w$  和输入  $x \in X$ ,  $\phi(x; w) \in F$  代表了网络  $\phi$  对输入  $x$  的特征表示。让  $c$  表示输出空间  $F$  中超球体的球心,则超

球约束优化目标为:

$$\min_w \frac{1}{N} \sum_{i=1}^N (\| \phi(x_i; w) - c \|^2)^{\tilde{y}_i} \quad (1)$$

式中:  $N$  表示脑电信号样本数量,  $\tilde{y}_i = \pm 1$ , 当  $x_i$  属于非目标脑电数据时,  $\tilde{y}_i = 1$ , 缩小非目标脑电数据与超球体球心  $c$  的距离; 当  $x_i$  属于目标脑电数据时,  $\tilde{y}_i = -1$ , 增加目标脑电数据与超球体球心  $c$  的距离。

#### 3) 多任务损失函数构造

本文多任务损失函数由分类任务对应的带权重的交叉熵损失函数  $L_{WCE}$  和超球约束任务对应的带权重的 SVDD 损失函数  $L_{WSVDD}$  构成,多任务损失函数定义为:

$$Loss = L_{WCE} + \gamma L_{WSVDD} \quad (2)$$

式中:  $\gamma$  为损失权重系数,用于平衡交叉熵损失和 SVDD 损失。

(1) 带权重的交叉熵损失函数:针对 RSVP 脑电数据的样本不平衡问题,采用带权重的交叉熵损失函数  $L_{WCE}$  进行网络训练,具体形式为:

$$L_{WCE} = - \frac{1}{N} \times \sum_{i=1}^N (\omega_1 y_i \log(p_i) + \omega_0 (1 - y_i) \log(1 - p_i)) \quad (3)$$

式中:  $y_i$  表示第  $i$  个脑电数据的标签值,其中非目标脑电数据  $y_i = 0$ , 目标脑电数据  $y_i = 1$ ,  $p_i$  表示第  $i$  个脑电数据被预测为目标概率。 $\omega_1$  和  $\omega_0$  分别表示目标和非目标脑电数据的权值系数,它们的值取决于两类脑电数据数



量。正常情况下,  $\omega_1 > \omega_0$ , 以此增强网络对目标脑电数据的关注, 减弱对非目标脑电数据的关注。

(2) 带权重的 SVDD 损失函数: 为使特征提取网络得到的非目标脑电特征位于超球体内部, 目标脑电特征位于超球体外部, 这里增加目标特征到超球体球心的距离, 同时减少非目标特征到超球体球心的距离, 由此定义的带权重的 SVDD 损失函数  $L_{WSVDD}$  如下:

$$L_{WSVDD} = \frac{1}{N} \sum_{i=1}^N (\|\phi(x_i; w) - c\|^2)^{(-1)^{y_i}} \times \delta^{y_i} \quad (4)$$

式中:  $\delta$  是加权系数, 通过调整  $\delta$  值, 可以实现模型对目标脑电数据关注程度的调节。当  $\delta > 1$  时, 会增强模型对目标脑电数据的关注, 当  $\delta < 1$  时, 会减弱模型对目标脑电数据的关注。由于 RSVP 脑电数据有标签, 因此通过减小目标脑电特征到球心  $c$  距离的倒数, 来增加目标脑电特征与超球体的距离, 这也相当于增加目标脑电特征与非目标脑电特征的距离。相较于只使用非目标脑电特征来构造和训练超球体, 同时使用 2 种脑电特征构造的超球体更紧凑, 目标脑电特征与非目标脑电特征的差异也更大, 从而提高分类效果。

为在训练过程中平衡交叉熵损失和 SVDD 损失的贡献, 可以使用一个固定的超参数  $\gamma$ , 它的值是神经网络与超球体初始化时利用训练集脑电数据计算得到的 2 个损失函数之比, 即:

$$\gamma = \gamma_{init} = \frac{L_{WCE}^{init}}{L_{WSVDD}^{init}} \quad (5)$$

这样可以确保两个损失函数在训练中有相同的权重, 从而更好地优化整个模型。

(3) 球心损失函数: 本文将神经网络参数与超球体球心参数分开进行训练, 因此除多任务损失函数之外, 还存在球心损失函数  $L_{CENTER}$ , 具体定义如下:

$$L_{CENTER} = \left\| \frac{1}{N} \times \sum_{i=1}^N \phi(x_i; w) \times (1 - y_i) - c \right\|^2 \quad (6)$$

该损失函数的物理意义是将当前的球心  $c$  向训练集中的非目标脑电特征的中心靠拢, 以达到最小尺寸的超球体能够囊括整个非目标特征的效果。

## 2 实验结果

### 2.1 实验数据集

#### 1) 数据集

本文所用数据集源于清华大学脑机接口研究组于 2020 年发布的 RSVP 基准数据集, 主要进行街景图像分类任务。这些街景图像中包含行人的图像为目标图像, 其他图像则为非目标图像。该数据集采集了 64 名健康受试者共 64 通道脑电数据。该 RSVP 范式实验按时间先后顺序分为 2 组, 每组共有 2 个区块, 每个区块包含

40 个试次, 每个试次呈现 100 张刺激图像, 只有随机 1~4 张为目标图像, 其余均为非目标图像, 如图 3 所示。

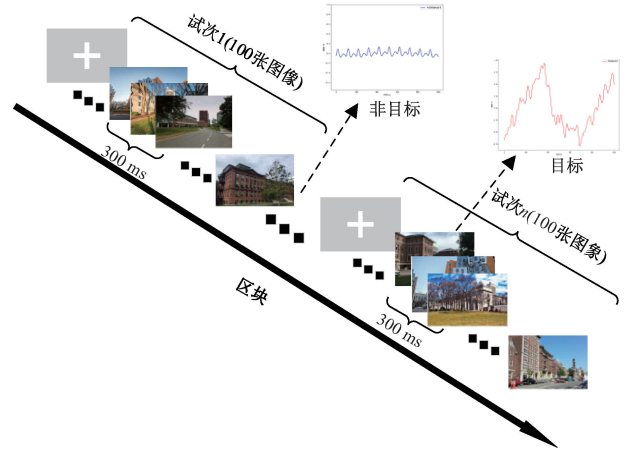


图3 RSVP 范式示意图

Fig. 3 The diagram of RSVP paradigm

#### 2) 数据预处理

为了避免受试者内变异性的影响, 本文仅使用前 36 个受试者第一组的 8 000 个脑电数据进行实验。其中受试者 1~4 的脑电数据用于超参数确定, 而后 32 个受试者的脑电数据则用于算法性能评估。对每个受试者的原始脑电数据, 按照以下步骤进行预处理: 首先进行坏道剔除, 然后利用 3 阶巴特沃斯滤波器进行 0.1~40 Hz 带通滤波, 接着利用 -200~0 ms 的脑电数据进行去基线操作, 再将脑电数据按 0~1 024 ms 进行分段, 最后将脑电数据降采样到 125 Hz。在处理完成后, 将每个受试者的数据按 8:2 的比例划分为训练集和测试集, 并将训练集等分为 5 份以进行 5 折交叉验证实验。

### 2.2 实验参数配置

在训练阶段, 我们将批量大小设置为 256, 并使用 Adam 优化器训练网络参数。其中权重衰退参数设置为 0.001、0.000 1 以及 0.000 01 时分类性能不存在显著差异, 同时设置为 0.000 1 时模型训练更稳定, 因此权重衰退参数采用 0.000 1。初始学习率为 0.001, 当连续 5 个 epoch 的验证集总损失不下降时, 就将学习率减半以避免过拟合。同时, 使用 Adagrad 优化器来训练超球体球心, 初始学习率也为 0.001, 学习率衰退参数设置为 0.000 1。为避免过拟合并减少训练时间, 这里还设置了早停策略, 即当连续 15 个 epoch 的验证集总损失不下降时停止训练, 并保存验证集总损失最低时的网络参数。

实验所用硬件配置为: 12 核 Intel (R) Xeon (R) Platinum 8255C CPU @ 2.50 GHz, 内存: 45 GB, GPU 加速显卡: RTX3080 显存 10 G。深度学习开发平台为 Pytorch1.7.0 框架。




### 2.3 超参数讨论

为了确定最佳超参数,本节进行了超参数的讨论实验。实验采用前 4 个受试者 (sub1~sub4) 的数据进行模型分类性能评估,使用 ROC 曲线下面积 (area under curve, AUC) 作为评估指标,通过不同超参数的组合确定最佳超参数,并将其应用于最终模型中。


#### 1) 基本模型训练参数

本节主要研究模型训练过程中网络训练学习率  $lr_1$ 、超球体球心训练学习率  $lr_2$  以及网络与球心的训练数据比例  $K$  (表示训练集中  $K \times 100\%$  的数据用于训练特征提取网络,剩余数据训练超球体球心) 对模型分类性能的影响。超参数的搜索空间分别为  $lr_1 = \{0.1, 0.01, 0.001, 0.0001\}$ ,  $lr_2 = \{0.1, 0.01, 0.001, 0.0001\}$ ,  $K = \{0.5, 0.6, 0.7, 0.8, 0.9\}$ , 图 4 展示了不同参数组合下模型分类性能。



(a) 最佳球心训练学习率 ( $lr_2=0.001$ ) 下不同  $K$  与不同网络训练学习率  $lr_1$  对应的 AUC

(a) AUC corresponding to different values of  $K$  and varying network training learning rates ( $lr_1$ ) were obtained under the optimal learning rate ( $lr_2=0.001$ ) for center training



(b) 最佳网络训练学习率 ( $lr_1=0.001$ ) 下不同  $K$  与不同球心训练学习率  $lr_2$  对应的 AUC

(b) AUC corresponding to different values of  $K$  and varying center training learning rates ( $lr_2$ ) were obtained under the optimal learning rate ( $lr_1=0.001$ ) for network training

图 4 不同  $lr_1$ 、 $lr_2$  和  $K$  取值下 4 个受试者平均 AUC 对比

Fig. 4 Average AUC of 4 subjects under different  $lr_1$ 、 $lr_2$  and  $K$

从图 4(a) 可以看出,网络训练学习率为 0.001 时,大部分  $K$  值下模型分类效果达到最佳。当  $lr_1 = 0.1$  时,由于学习率过大,同时  $K=0.5$  和 0.6 导致网络训练数据较少,再加上受试者 2 的数据质量较差,使网络训练不充

分,影响了 4 个受试者的平均 AUC,造成菱形折线与其他折线有明显差距。图 4(b) 中显示,不同的球心训练学习率下,模型分类性能存在波动,本文选择了效果最好的一组参数,即  $K = 0.9$ ,  $lr_2 = 0.001$ 。综上所述,在  $lr_1 = 0.001$ ,  $lr_2 = 0.001$ ,  $K = 0.9$  的情况下,模型训练的分类性能最佳。

#### 2) 多任务损失函数参数优化实验

(1) SVDD 损失函数中的加权系数  $\delta$ 。考虑到非目标脑电数据数量远多于目标脑电数据,并且 SVDD 损失函数中目标脑电特征与超球体球心  $c$  距离取倒数这一项会随着网络优化逐渐减小,可能减弱模型对目标脑电特征远离超球体这一约束。因此,本文引入加权系数  $\delta$  以增加模型对目标脑电数据的关注度,提高训练效果。不同  $\delta$  取值下模型性能如表 1 所示。实验结果表明,当  $\delta = 5$  时,模型性能最佳。

表 1 不同  $\delta$  下 4 个受试者平均 AUC 对比

$\delta$	平均 AUC/%
1	88.23
5	<b>88.64</b>
10	88.50
50	87.70
100	88.08
500	87.96
1 000	87.65

根据实验结果,分析可能是由于更大的加权系数  $\delta$  虽然会使模型加强对目标脑电特征远离超球体球心的约束,但同时会减弱使超球体学习得尽量紧凑这一约束,导致非目标脑电特征与目标脑电特征差异性降低,从而影响分类效果。因此为平衡超球中多个约束, $\delta$  值不能过大,选择为 5 较为合适。

(2) 多任务损失函数中的权值系数  $\gamma$ 。多任务损失函数包括带权重的交叉熵损失  $L_{wce}$  和带权重的 SVDD 损失  $L_{wsvdd}$ ,为了平衡两者的作用,本文引入权值系数  $\gamma$ 。选择网络初始化后通过训练集得到的  $L_{wce}$  和  $L_{wsvdd}$  的比值  $\gamma_{init}$  作为最终权值系数,以确保 2 个损失函数对模型的贡献相当。由于不同  $\gamma$  取值会影响模型的性能和收敛速度,因此本文还尝试了其他取值,不同取值下模型分类性能如表 2 所示。实验结果表明,当  $\gamma = \gamma_{init} = L_{wce}^{init} : L_{wsvdd}^{init}$  时,模型分类性能达到最佳。这种取值可以加速模型的收敛速度,同时提高模型的泛化能力,从而使模型在分类任务中表现更好。由于  $\gamma_{init}$  受到随机种子以及数据的影响,不同受试者模型的  $\gamma_{init}$  值不一样,因此  $\gamma_{init}$  具体数值表中并未列出。

表2 不同  $\gamma$  下4个受试者平均 AUC 对比Table 2 Average AUC of 4 subjects under different  $\gamma$  values

$\gamma$	平均 AUC/%
$\gamma_{init}$	<b>88.64</b>
1:1	74.66
1:2	63.94
2:1	77.84
5:1	86.80
10:1	87.91
20:1	87.94
50:1	87.44
100:1	86.70

### 3) 任务对比实验

为了证明多任务学习相对于单任务学习的性能提升,本文进行了对比试验,分别为仅进行分类任务学习和仅进行超球约束任务学习。由于仅进行超球约束任务学习时没有带权重的交叉熵损失函数与之一起训练,对于超球体球心的训练可能会引发超球体崩塌<sup>[21]</sup>。因此,在这一实验下必须固定球心并将激活函数从  $\text{elu}$  改为  $\text{relu}$ 。我们使用训练初始化时,非目标脑电特征的中心点作为球心  $c_1$ ,同时随机初始化一个球心  $c_2$ ,分别进行实验。另外,对于超球约束单任务学习,我们采用训练集中非目标脑电特征与球心  $c$  距离的 0.9 分位数作为阈值,用于判断测试集脑电特征是否为非目标。这是由于非目标脑电特征中可能会存在干扰,使个别异常的非目标脑电特征与球心  $c$  之间的距离过大,接近甚至超过了目标脑电特征与球心  $c$  之间的距离,从而使模型无法对目标脑电特征进行正确分类。

为了对比球心是否可训练对分类性能的影响,我们也进行了多任务学习时固定球心分别为  $c_1$  和  $c_2$  的实验,实验结果如表 3 所示。可以看出,当同时进行分类任务与超球约束任务联合学习,并且超球体球心可训练时,模型的性能最佳。

表3 不同实验设置下的4个受试者平均 AUC

Table 3 Average AUC of 4 subjects under different experiment settings

实验设置	平均 AUC/%
分类单任务学习	85.60
超球约束单任务学习(固定球心 $c=c_1$ )	79.97
超球约束单任务学习(固定球心 $c=c_2$ )	53.01
多任务学习(固定球心 $c=c_1$ )	78.70
多任务学习(固定球心 $c=c_2$ )	88.35
多任务学习(球心 $c$ 可训练)	<b>88.64</b>

当固定球心为  $c_1$  进行多任务学习时,初始  $L_{\text{wsvdd}}$  较小且很快收敛,限制了网络参数改变范围,使分类任务不能得到充分训练,造成 AUC 偏低。另外根据表 3 的结果,当使用固定球心  $c_1$  的超球约束单任务学习时,4 个受试者的平均 AUC 达到了 79.97%,这表明超球约束确实有助于模型学习判别特征。这也证实了将异常检测领域的单分类方法 SVDD 引入 EEG 领域是一个成功的尝试。同时,这也说明分类任务和超球约束任务存在相关性,带权重的交叉熵损失函数和带权重的 SVDD 损失函数都有助于在缓解样本不平衡问题的情况下,帮助模型学习并提取判别特征。因此,多任务学习联合训练相比单任务学习可以取得更好的结果。

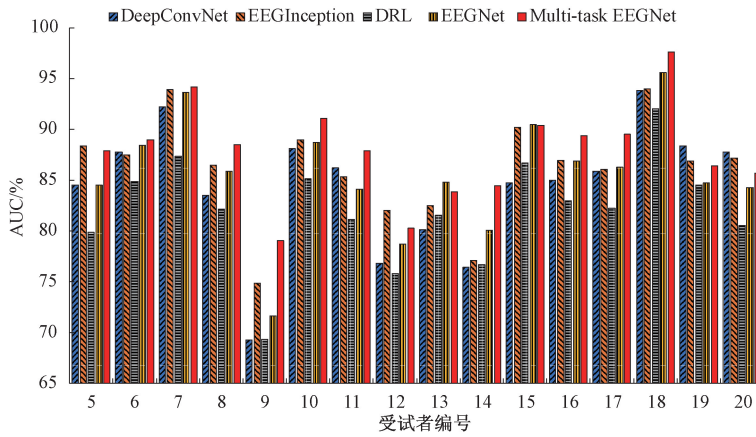
### 2.4 总体实验结果

为了评估本文提出的 Multi-task 模型在缓解样本不平衡问题下的分类性能,本研究选用了 4 种模型进行实验,包括 DeepConvNet<sup>[16]</sup>、EEGInception<sup>[18]</sup>、DRL<sup>[13]</sup> 和 EEGNet<sup>[17]</sup> 模型。这些模型在 BCI 领域对 EEG 进行解码和分类任务上表现优秀。

为了得到可靠的结果,本研究对 32 个受试者进行了 5 折交叉验证。各模型的 RSVP 分类性能对比如图 5 和表 4 所示。实验结果显示,本文提出的 Multi-task EEGNet 模型在分类性能上表现最好,在 32 个受试者中平均 AUC 达到了 90.56%。相较于 DeepConvNet、EEGInception、DRL 以及 EEGNet 模型,该模型的性能分别提升了 3.57%、1.84%、6.22% 和 2.09%。值得一提的是,在 32 个受试者中,Multi-task EEGNet 模型有 23 个受试者的 5 折平均 AUC 超过了其他 4 个模型,位居第一,而另外 9 个受试者中有 7 个受试者使用该模型得到的 AUC 结果位居第二,验证了该模型的通用性。


## 3 结论

本文提出一种基于多任务学习的 RSVP 脑电图分类模型,将异常检测领域的单分类思想引入 EEG 分类中,利用带权重的交叉熵损失函数和带权重的 SVDD 损失函数来缓解 RSVP 脑电数据的样本不平衡问题。同时,联合学习分类任务和超球约束任务,使两任务之间相互促进,提高模型对判别特征的提取能力,最终提高模型的泛化性和分类性能。本文在 RSVP 公开数据集上进行了 5 折交叉验证实验,提出的 Multi-task EEGNet 模型相比基准算法 EEGNet 模型 32 个受试者平均 AUC 提升了 2.09%。同时,相较于目前最好的几种脑电分类模型 DeepConvNet、EEGInception 和 DRL 模型,32 个受试者平均 AUC 分别提升了 3.57%、1.84% 和 6.22%。因此,本文提出的基于多任务学习的 RSVP 脑电图分类模型能够



(a) 不同模型对受试者5~20脑电分类性能对比

(a) Comparison of classification performance of EEG signals from subjects 5~20 among different models



(b) 不同模型对受试者21~36脑电分类性能对比

(b) Comparison of classification performance of EEG signals from subjects 21~36 among different models

图 5 不同模型对 32 个受试者脑电分类性能对比

Fig. 5 Comparison of EEG classification performance among 32 subjects using different models

表 4 不同模型对 32 个受试者脑电分类性能对比

Table 4 Comparison of EEG classification performance among 32 subjects using different models

受试者	AUC/%				
	DeepConvNet <sup>[16]</sup>	EEGInception <sup>[18]</sup>	DRL <sup>[13]</sup>	EEGNet <sup>[17]</sup>	Multi-task EEGNet
5	84.52	<b>88.37</b>	79.84	84.51	87.86
6	87.75	87.51	84.84	88.39	<b>88.93</b>
7	92.19	93.87	87.32	93.61	<b>94.15</b>
8	83.51	86.43	82.13	85.88	<b>88.49</b>
9	69.27	74.86	69.29	71.61	<b>79.05</b>
10	88.11	88.95	85.09	88.68	<b>91.08</b>
11	86.17	85.29	81.14	84.12	<b>87.87</b>
12	76.80	<b>81.98</b>	75.81	78.69	80.23
13	80.15	82.49	81.56	<b>84.78</b>	83.81
14	76.39	77.11	76.70	80.02	<b>84.47</b>
15	84.68	90.17	86.65	<b>90.48</b>	90.40
16	85.00	86.91	82.93	86.85	<b>89.35</b>



续表4

受试者	AUC/%				
	DeepConvNet <sup>[16]</sup>	EEGINception <sup>[18]</sup>	DRL <sup>[13]</sup>	EEGNet <sup>[17]</sup>	Multi-task EEGNet
17	85.85	86.08	82.23	86.26	<b>89.53</b>
18	93.82	93.96	92.02	95.57	<b>97.62</b>
19	<b>88.34</b>	86.90	84.49	84.71	86.41
20	<b>87.72</b>	87.12	80.50	84.21	85.63
21	85.09	90.54	83.74	90.11	<b>94.38</b>
22	95.32	96.02	92.54	95.87	<b>97.58</b>
23	79.96	<b>86.13</b>	81.35	83.92	86.02
24	86.54	88.65	85.39	88.91	<b>91.58</b>
25	92.95	95.17	89.41	95.01	<b>97.10</b>
26	92.69	91.95	87.19	90.76	<b>94.19</b>
27	<b>92.09</b>	89.81	81.98	90.91	91.67
28	97.90	99.30	96.84	99.46	<b>99.81</b>
29	85.11	85.51	80.14	85.63	<b>87.27</b>
30	90.92	91.89	86.48	95.16	<b>96.92</b>
31	91.92	<b>93.65</b>	84.10	91.24	93.20
32	89.43	90.17	89.05	91.11	<b>94.33</b>
33	82.29	85.32	82.31	84.69	<b>86.35</b>
34	86.05	87.70	84.59	89.29	<b>90.83</b>
35	91.17	92.91	90.31	94.53	<b>95.06</b>
36	93.93	96.20	90.94	96.10	<b>96.87</b>
平均	86.99	88.72	84.34	88.47	<b>90.56</b>

有效缓解样本不平衡问题,增强对判别特征的提取能力,提高分类性能,为解决样本不平衡的 EEG 分类任务提供了新的思路。

### 参考文献

- [ 1 ] NICOLAS A L F, GOMEZ S J. Brain computer interfaces, a review[J]. *sensors*, 2012, 12(2): 1211-1279.
- [ 2 ] CECOTTI H, GRASER A. Convolutional neural networks for P300 detection with application to brain-computer interfaces[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2010, 33(3): 433-445.
- [ 3 ] CHAUDHARY U, XIA B, SILVONI S, et al. Brain-computer interface-based communication in the completely locked-in state [ J ]. *PLoS biology*, 2017, 15(1): 1002593.
- [ 4 ] 刘晋瑞, 宋婷, 舒智林, 等. 一种面向运动解码的 EEG-fNIRS 时频特征融合与协同分类方法[J]. *仪器仪表学报*, 2022, 43(7): 165-173.
- LIU J R, SONG T, SHU ZH L, et al. A time-frequency feature fusion and collaborative classification method for

motion decoding with EEG-fNIRS signals [ J ]. *Chinese Journal of Scientific Instrument*, 2022, 43 ( 7 ): 165-173.

- [ 5 ] 康显赞, 刘爽, 苏方玥, 等. 基于 HFD 和 LZC 特征联合的单通道静息态脑电抑郁症识别研究[J]. *仪器仪表学报*, 2022, 43(7): 181-190.
- KANG X Y, LIU SH, SU F Y, et al. Research on the identification of single-channel resting-state EEG recognition of depression based on the combination features of HFD and LZC [ J ]. *Chinese Journal of Scientific Instrument*, 2022, 43(7): 181-190.
- [ 6 ] 费洪磊, 袁琦, 郑玉叶. 基于深度学习的癫痫脑电不平衡分类方法[J]. *仪器仪表学报*, 2021, 42(3): 231-240.
- FEI H L, YUAN Q, ZHENG Y Y. Imbalanced classification for epileptic EEG signals based on deep learning [ J ]. *Chinese Journal of Scientific Instrument*, 2021, 42(3): 231-240.
- [ 7 ] 李解放, 徐建军, 孙铭阳, 等. 基于 RSVP 的面向不良信息检测人机协作系统研究[J]. *电子测量与仪器*

- 学报, 2022, 36(6): 22-29.
- LI J F, XU J J, SUN M Y, et al. Research on human-machine cooperation system for bad information detection based on RSVP[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 22-29.
- [ 8 ] LEES S, DAYAN N, CECOTTI H, et al. A review of rapid serial visual presentation-based brain-computer interfaces [J]. Journal of neural engineering, 2018, 15(2): 021001.
- [ 9 ] HOFFMANN U, GARCIA G, VESIN J M, et al. A boosting approach to P300 detection with application to brain-computer interfaces[C]. Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering, IEEE, 2005: 97-100.
- [ 10 ] POLICH J, DONCHIN E. P300 and the word frequency effect[J]. Electroencephalography and clinical neurophysiology, 1988, 70(1): 33-45.
- [ 11 ] 崔玉洁, 谢松云, 谢辛舟, 等. 针对快速序列视觉呈现脑电信号的时空混合特征提取方法[J]. 生物医学工程学杂志, 2022, 39(1): 39-46.
- CUI Y J, XIE S Y, XIE X Z H, et al. A spatial-temporal hybrid feature extraction method for rapid serial presentation of electroencephalogram signals[J]. Journal of Biomedical Engineering, 2022, 39(1): 39-46.
- [ 12 ] GALAR M, FERNANDEZ A, BARRENECHEA E, et al. A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2011, 42(4): 463-484.
- [ 13 ] LI F, LI H, LI Y, et al. Decoupling representation learning for imbalanced electroencephalography classification in rapid serial visual presentation task[J]. Journal of Neural Engineering, 2022, 19(3): 036011.
- [ 14 ] XU M, CHEN Y, WANG Y, et al. BWGAN-GP: An EEG data generation method for class imbalance problem in RSVP tasks[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 251-263.
- [ 15 ] WANG S, LIU W, WU J, et al. Training deep neural networks on imbalanced data sets[C]. 2016 international joint conference on neural networks (IJCNN), IEEE, 2016: 4368-4374.
- [ 16 ] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. Human brain mapping, 2017, 38(11): 5391-5420.
- [ 17 ] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces[J]. Journal of neural engineering, 2018, 15(5): 056013.
- [ 18 ] SANTAMARIA V E, MARTINEZ-C V, VAQUER V F, et al. EEG-inception: A novel deep conv-olutional neural network for assistive ERP-based brain-computer interfaces[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(12): 2773-2782.
- [ 19 ] PANG G, SHEN C, CAO L, et al. Deep learning for anomaly detection: A review [J]. ACM computing surveys (CSUR), 2021, 54(2): 1-38.
- [ 20 ] TAX D M J, DUIN R P W. Support vector data description[J]. Machine learning, 2004, 54: 45-66.
- [ 21 ] RUFF L, VANDERMEULEN R, GOERNITZ N, et al. Deep one-class classification [C]. International conference on machine learning, PMLR, 2018: 4393-4402.
- [ 22 ] AKHTAR M S, GHOSAL D, EKBAL A, et al. All-in-one: Emotion, sentiment and intensity prediction using a multi-task ensemble framework[J]. IEEE transactions on affective computing, 2019, 13(1): 285-297.
- [ 23 ] LI C, WANG B, ZHANG S, et al. Emotion recognition from EEG based on multi-task learning with capsule network and attention mechanism [J]. Computers in Biology and Medicine, 2022, 143: 105303.

### 作者简介



谢平, 分别在 1993 年、1996 年和 2006 年于燕山大学获得学士、硕士以及博士学位, 现为燕山大学教授, 主要研究方向为脑机接口、智能康复等。

E-mail: pingx@ysu.edu.cn

**Xie Ping** received her B. Sc., M. Sc. and Ph. D. degrees all from Yanshan University in 1993, 1996 and 2006. She is currently a professor at Yanshan University. Her main research interests include brain-computer interface and intelligent rehabilitation.



江国乾(通信作者), 分别在 2011 年和 2017 年于燕山大学获得学士学位和博士学位, 现为燕山大学副教授, 主要研究方向为智能信息处理、智能计算等。

E-mail: jiangguoqian@ysu.edu.cn

**Jiang Guoqian** (Corresponding author) received his B. Sc. degree and Ph. D. degree both from Yanshan University in 2011 and 2017. He is currently an associate professor at Yanshan University. His main research interests include intelligent information processing and intelligent computing.